

# Appunti di Probabilità e Statistica

a.a. 2014/2015 C.d.L. Informatica –  
Bioinformatica  
I. Oliva

Lezione 5

## 1 Momenti di v.a.

Vogliamo associare alle v.a. delle grandezze deterministiche, che ne diano informazioni qualitative e quantitative.

**Media** Se  $X$  è una v.a. discreta con supporto  $S = \{k : k \in I\}$ ,  $I \subset \mathbb{Z}$ , e con densità  $P(X = k)$  e se supponiamo che  $\sum_{k \in S} |k|P(X = k) < \infty$ , si chiama *media* di  $X$  la quantità

$$E(X) := \sum_{k \in S} kP(X = k).$$

**Esempio 1.1.**  $X$  : guadagno netto puntando un euro sul rosso alla roulette onesta,  $Y$  : guadagno netto puntando un euro su  $T$  nel lancio di una moneta equa.

$X, Y$  sono v.a. discrete, entrambe con supporto  $\pm 1$ . Inoltre,  $P(X = 1) = 18/37$ ,  $P(X = -1) = 19/37$ ,  $P(Y = 1) = P(Y = -1) = 1/2$ . Allora, avremo:

$$E(X) = 1 \cdot \frac{18}{37} + (-1) \cdot \frac{19}{37} = -\frac{1}{37}$$
$$E(Y) = 1 \cdot \frac{1}{2} + (-1) \cdot \frac{1}{2} = 0$$

Se  $X$  è una v.a. continua con densità  $f_x$  e se supponiamo che  $\int_{\mathbb{R}} |x|f_X(x)dx < \infty$ , si chiama *media* di  $X$  la quantità

$$E(X) := \int_{\mathbb{R}} xf_X(x)dx .$$

### Proprietà della media

1. (*coerenza*) Se  $P(X = c) = 1$ , allora  $E(X) = c$ . Infatti:  
se  $P(X = c) = 1$ , allora, per definizione di media,  $E(X) = c \cdot P(X = c) = c$ .
2. (*linearità*) Se  $E(X) < \infty$  e  $a, b$  sono due costanti, allora  $E(aX + b) = aE(X) + b$ . Infatti:  
se  $X$  è v.a. discreta, allora

$$\begin{aligned} E(aX + b) &= \sum_{k \in I} (ak + b)P(X = k) = a \sum_{k \in I} kP(X = k) \\ &\quad + b \sum_{k \in I} P(X = k) = aE(X) + b; . \end{aligned}$$

Se  $X$  è v.a. continua, allora

$$\begin{aligned} E(aX + b) &= \int_{\mathbb{R}} (ax + b)f_X(x)dx \\ &= a \int_{\mathbb{R}} xf_X(x)dx + b \int_{\mathbb{R}} f_X(x)dx = aE(X) + b; . \end{aligned}$$

3. (*internalità*) Se  $a, b \in \mathbb{R}$  sono tali che  $P(a \leq X \leq b) = 1$ , allora  $a \leq E(X) \leq b$ . Infatti:  
se  $P(a \leq X \leq b) = 1$ , allora, per definizione di media, esiste  $E(X)$ . In particolare,  $P(X - a) \geq 0$ , dunque

$$0 \leq E(X - a) = E(X) - E(a) = E(X) - a .$$

Analogamente,  $P(b - X) \geq 0$ , dunque

$$0 \leq E(b - X) = E(b) - E(X) = b - E(X) .$$

La media si chiama anche *momento primo*, in quanto si possono definire i *momenti di ordine  $i$* , per ogni  $i \geq 1$  :

$$E(X^i) = \sum_{k \in I} k^i P(X = k) .$$

**Varianza** Se  $X$  è una v.a. (discreta o continua), per cui esiste  $E(X)$  e  $E((X - E(X))^2)$ , si chiama *varianza* di  $X$  la quantità

$$Var(X) = E((X - E(X))^2) .$$

**Esempio 1.2.**  $Y$  : guadagno netto puntando 1 € su  $T$  nel lancio di una moneta equa,  $Z$  : guadagno netto puntando 1000 € su  $T$  nel lancio di una moneta equa. Avremo:

$$P(Y = 1) = P(Y = -1) = 1/2, P(Y = 1000) = P(Y = -1000) = 1/2 .$$

Inoltre,  $E(Y) = E(Z) = 0$ . Per quel che riguarda la varianza:

$$Var(Y) = E((Y - E(Y))^2) = E(Y^2)$$

$$= \sum_{k \in \{-1,1\}} k^2 P(X = k) = (-1)^2 \cdot \frac{1}{2} + 1^2 \cdot \frac{1}{2} = 1$$

$$Var(Z) = E((Z - E(Z))^2) = E(Z^2)$$

$$= \sum_{k \in \{-10^3, 10^3\}} k^2 P(X = k) = (-1000)^2 \cdot \frac{1}{2} + 1000^2 \cdot \frac{1}{2} = 10^6$$

### Proprietà della varianza

1.  $Var(X) = 0$  se e solo se  $P(X = c) = 1$ . Infatti:  
se  $P(X = c) = 1$ , allora  $E(X) = c$  e  $Var(X) = E((c - c)^2) = 0$ .  
Viceversa, se  $Var(X) = 0$ , essendo  $P((X - E(X))^2 \geq 0) = 1$ , allora  $P((X - E(X))^2 = 0) = 1$ , che si verifica se e solo se  $P(X = E(X)) = 1$ .
2. Se  $X$  ammette varianza e  $a, b \in \mathbb{R}$ , allora  $Var(aX + b) = a^2 Var(X)$ .  
Infatti:

$$\begin{aligned} Var(aX + b) &= E((aX + b - E(aX + b))^2) \\ &= E((aX + b - aE(X) - b)^2) = E((aX - aE(X))^2) \\ &= a^2 E((X - E(X))^2) = a^2 Var(X). \end{aligned}$$

3. Se  $X$  ammette varianza, allora  $X^2$  ammette media e  $Var(X) = E(X^2) - (E(X))^2$ . Infatti:

Se  $X$  ammette varianza, allora

$$\begin{aligned} E(X^2) &= E((X - E(X) + E(X))^2) \leq E((X - E(X))^2 + E(X))^2 \\ &\leq 2E((X - E(X))^2) + 2E(X)^2 \\ &= \text{Var}(X) + 2E(X)^2 < \infty \end{aligned}$$

Questo garantisce che il momento secondo esiste. Inoltre:

$$\begin{aligned} \text{Var}(X) &= E((X - E(X))^2) = E(X^2 - 2XE(X) + E(X)^2) \\ &= E(X^2) - E(X)^2. \end{aligned}$$

**Esercizio 1.1.** Sia  $X \sim \text{Bin}(n, p)$ . Allora  $E(X) = np$  e  $\text{Var}(X) = np(1 - p)$ .

**Esercizio 1.2.** Sia  $X \sim \text{Po}(\lambda)$ . Allora  $E(X) = \lambda$  e  $\text{Var}(X) = \lambda$ .

**Esercizio 1.3.** Sia  $X \sim \mathcal{U}(0, 1)$ . Allora  $E(X) = \frac{1}{2}$  e  $\text{Var}(X) = \frac{1}{12}$ . In generale, se  $X \sim \mathcal{U}(a, b)$ , allora  $E(X) = \frac{a+b}{2}$  e  $\text{Var}(X) = \frac{(a+b)^2}{12}$ .

**Esercizio 1.4.** Sia  $X \sim \text{Exp}(\mu)$ . Allora  $E(X) = \frac{1}{\lambda}$  e  $\text{Var}(X) = \frac{1}{\lambda^2}$ .

**Esercizio 1.5.** Sia  $X \sim \mathcal{N}(0, 1)$ . Allora  $E(X) = 0$  e  $\text{Var}(X) = 1$ . In generale, se  $X \sim \mathcal{N}(\mu, \sigma^2)$ , allora  $E(X) = \mu$  e  $\text{Var}(X) = \sigma^2$ .

## 2 Teoremi classici per le variabili aleatorie

Esistono alcuni importanti risultati che permettono di determinare una approssimazione della probabilità, quando le variabili aleatorie coinvolte non hanno distribuzione nota.

**Disuguaglianza di Markov** Sia  $X$  una v.a. non negativa, allora, per qualunque valore  $a > 0$ , si ha

$$P(X \leq a) \leq \frac{E(X)}{a}.$$

*Proof.* Verifichiamo la disuguaglianza nel caso di v.a. continue (il caso discreto risulta analogo). Sia  $X$  una v.a. con densità  $f$ , allora

$$\begin{aligned} E(X) &= \int_{\mathbb{R}} xf(x)dx = \int_0^{\infty} xf(x)dx = \int_0^a xf(x)dx + \int_a^{\infty} xf(x)dx \\ &\geq \int_a^{\infty} xf(x)dx \geq \int_a^{\infty} af(x)dx = a \int_a^{\infty} f(x)dx \\ &= aP(X \geq a). \end{aligned}$$

□

**Esempio 2.1.** Una moneta non equa, in cui la probabilità che esca testa è  $1/10$ , viene lanciata 200 volte. Determinare una stima della probabilità che, su 200 lanci, esca testa almeno 120 volte.

Sia  $X$  la v.a. che conta il numero di teste su  $n = 200$  lanci, allora  $X \sim \text{Bin}(200, 1/10)$ . Si tratta di calcolare, allora,  $P(X \geq 120)$ , ma è un numero troppo grande da calcolare "a mano"! Usiamo, dunque, la Disuguaglianza di Markov con  $a = 120$  e  $E(X) = np = 200 \cdot \frac{1}{10} = 20$  e avremo

$$P(X \geq 120) \leq \frac{20}{120} = \frac{1}{6}.$$

**Disuguaglianza di Chebychev** Sia  $X$  una v.a. con media  $E(X)$  e varianza  $\text{Var}(X)$ . Allora, dato un qualunque valore  $k > 0$ , vale la seguente relazione

$$P(|X - E(X)| \geq k) \leq \frac{\text{Var}(X)}{k^2}.$$

*Proof.* Si consideri l'evento  $A = \{|X - E(X)| \geq k\}$ . I valori di  $X$  e  $k$  che soddisfano la disuguaglianza dell'evento  $A$  sono gli stessi per cui si verifica l'evento  $B = \{(X - E(X))^2 \geq k^2\}$ , quindi la probabilità che si verifichi l'evento  $A$  o l'evento  $B$  è la stessa. Inoltre, la variabile casuale  $(X - E(X))^2$  è non negativa (essendo un quadrato), dunque si può applicare la disuguaglianza di Markov, con  $a = k^2$ , quindi

$$P(|X - E(X)| \geq k) = P((X - E(X))^2 \geq k^2) \leq \frac{E[(X - E(X))^2]}{k^2} = \frac{\text{Var}(X)}{k^2}.$$

□

**Esempio 2.2.** Il numero di automobili prodotte da una fabbrica in una settimana si distribuisce secondo una v.a.  $X$  con media pari a 50.

Qual è la probabilità che la produzione superi occasionalmente le 75 auto? E qual è la probabilità che la produzione sia compresa tra 40 e 60 pezzi, sapendo che la varianza della distribuzione è pari a 25?

Usiamo la Disuguaglianza di Markov per risolvere il primo punto:

$$P(X \geq 75) \leq \frac{50}{75} = 0.67$$

Per quel che riguarda la seconda domanda, si applica la Disuguaglianza di Chebychev con  $k = 10$

$$\begin{aligned} P(40 \leq X \leq 60) &= 1 - P(X \leq 40, X \geq 60) = 1 - P(|X - 50| \geq 10) \\ &\leq \frac{25}{100} = 0.75. \end{aligned}$$

**Legge dei Grandi Numeri** Sia  $\{X_n\}$  una successione di v.a.i.i.d. che ammettono momento secondo e sia  $S_n := \frac{1}{n} \sum_{j=1}^n X_j$ . Allora, per ogni  $k > 0$ , si ha

$$\lim_{n \rightarrow \infty} P(|S_n - E(X)| > k) = 0 .$$

A parole, la media dei campionamenti converge, in senso stocastico, al valore atteso della popolazione, quando la dimensione del campione aumenta.

*Proof.* Siano  $m, s^2$  la media e la varianza di  $X_j$ , rispettivamente. Essendo le v.a. i.d., allora

$$E(S_n) = E\left(\frac{1}{n} \sum_{j=1}^n X_j\right) = \frac{n \cdot m}{n} = m .$$

Inoltre, essendo le v.a. indipendenti, si ha:

$$Var(S_n) = Var\left(\frac{1}{n} \sum_{j=1}^n X_j\right) = \frac{1}{n^2} \sum_{j=1}^n s^2 = \frac{s^2}{n} .$$

Applichiamo la Disuguaglianza di Chebychev e avremo

$$P(|S_n - m| > k) \leq \frac{s^2}{nk^2} \rightarrow 0 .$$

□

**Teorema del Limite Centrale** Sia  $\{X_n\}$  una successione i.i.d. di v.a. che ammettono momento secondo e con varianza non nulla. Posto  $m = E(X_n)$ ,  $s^2 = Var(X_n)$ ,  $S_n = \frac{1}{n} \sum_{j=1}^n X_j$  e  $Z_n = \frac{S_n - m}{s} \sqrt{n}$ , allora, per ogni  $x \in \mathbb{R}$ , si ha

$$\lim_{n \rightarrow \infty} P(Z_n \leq x) = P(Z \leq x) ,$$

dove  $Z \sim \mathcal{N}(0, 1)$ .

Vediamone l'applicazione (non la dimostrazione) con un esempio.

**Esempio 2.3.** *Si lancia  $n$  volte un dado equo.*

1. *Se  $n = 1000$ , qual è la probabilità che il punteggio totale sia minore o uguale a 3400?*

2. Quanto grande deve essere  $n$  perché, con probabilità maggiore o uguale del 99%, il punteggio totale sia almeno  $3.3n$ ?
3. Quanto grande deve essere  $n$  perché, con probabilità maggiore o uguale del 99%, il punteggio totale sia almeno 500?

Risolvi i diversi quesiti. L'idea generale è considerare l' $i$ -esimo lancio del dado ed indicare con  $X_i$  il valore ottenuto, quindi prendere in esame la quantità

$$Z_n = \frac{S_n - m}{s} \sqrt{n}.$$

Infine, sostituire  $Z_n$  con  $Z$  per ottenere una approssimazione esplicita, ma calcolabile.

1. Si ha  $X_i \in \{1, 2, 3, 4, 5, 6\}$  e  $P(X_i = k) = 1/6$ , per ogni  $k = 1, \dots, 6$ . Dunque,  $E(X) = 3.5$  e  $Var(X) = 2.917$ . Allora,

$$\begin{aligned} P(S_{1000} \leq 3400) &= P(X_1 + \dots + X_{1000} \leq 3400) \\ &= P\left(\frac{S_n - m}{s} \sqrt{n} \leq \frac{3400 - m}{s} \sqrt{n}\right) = P(Z_n \leq -1.85) \\ &\cong P(Z \leq -1.85) = \Phi(-1.85) = 1 - \Phi(1.85) = 0.0322. \end{aligned}$$

2. Determiniamo  $n$  tale che  $P(X_1 + \dots + X_n \geq 3.3n) \geq 0.99$ . Quindi,

$$\begin{aligned} 0.99 &\leq P(S_n \geq 3.3n) = P\left(Z_n \geq \frac{3.3n - m}{s} \sqrt{n}\right) \\ &= P(Z_n \geq -0.117n) \cong P(Z \geq -0.117n) = \Phi(0.117n) \\ &\Rightarrow 0.117\sqrt{n} \geq 2.33 \Rightarrow \sqrt{n} \geq \frac{2.33}{0.117} = 19.91 \Rightarrow n \geq 396. \end{aligned}$$


3. Determiniamo  $n$  tale che  $P(X_1 + \dots + X_n \geq 500) \geq 0.99$ . Quindi,

$$\begin{aligned}
 0.99 &\leq P(S_n \geq 500) = P\left(Z_n \geq \underbrace{\frac{500 - m}{s}}_Q \sqrt{n}\right) \\
 &\cong P(Z \geq Q) \\
 &\Rightarrow \frac{500 - m}{s} \sqrt{n} \geq 2.33 \\
 &\Rightarrow -\frac{500}{n} \sqrt{n} + 3.5 \sqrt{n} \geq 3.97 \\
 &\Rightarrow 3.5n - 3.97 \sqrt{n} \sqrt{n} - 500 \geq 0 \\
 &\Rightarrow \sqrt{n} = 12.53 \Rightarrow n \geq 158.
 \end{aligned}$$

La Legge dei Grandi Numeri ed il Teorema del limite centrale hanno un vasto bacino di applicazioni:

- *Approssimazione di  $\pi$ .*

Un ago di lunghezza  $L$  viene gettato a caso in un pavimento, formato da linee parallele, distanti  $d$  l'una dall'altra e supponiamo  $L < d$ . Ci sono due alternative: o l'ago cade esattamente tra due righe, oppure ne interseca una. Qual è la probabilità che si verifichi la seconda eventualità?



Il setting matematico è il seguente: sia  $\alpha$  l'angolo formato dall'ago e da una delle righe del pavimento e sia  $x$  la distanza tra il centro dell'ago e la riga più vicina. Supponiamo che  $\varphi, x$  siano due v.a.i.i.d. (equiprobabili). In particolare,

$$AB = L, OK =: x, 0 \leq x \leq d/2, \widehat{BOH} =: \varphi, 0 < \varphi < \pi.$$



L'ago cade su una riga se

$$x < BH = \frac{L}{2} \sin(\varphi) .$$

Dunque, la probabilità che cerchiamo si calcola come rapporto tra casi favorevoli e casi possibili, dove i “casi possibili” sono tutti i punti del piano, compresi tra  $[0, d/2]$  e  $[0, \pi]$ , mentre i “casi possibili” sono tutti i punti del piano compresi tra l'equazione che descrive  $x$  e  $[0, \pi]$ , ossia

$$P_x = \frac{\int_0^\pi \frac{L}{2} \sin(\varphi) d\varphi}{\frac{\pi d}{2}} = \frac{\frac{L}{2} [-\cos(\varphi)]_0^\pi}{\frac{\pi d}{2}} = \frac{2L}{\pi d} .$$

Quanto vale questo numero? Supponiamo di effettuare  $N$  (grande) lanci e sia  $k$  il numero di volte in cui l'ago non interseca una riga, allora

$$P_x = \lim_{N \rightarrow \infty} \frac{k}{N} = \frac{2L}{\pi d} \Rightarrow \pi \approx \frac{2LN}{kd} ,$$

che rappresenta una stima per  $\pi$ .

Discorso analogo vale se  $L \geq d$  : ponendo  $x = \frac{L}{d}$ , la probabilità, cercata è

$$P_x = \frac{2}{\pi} \left( x - \sqrt{x^2 - 1} + \arcsin(x) \right) .$$

- *Metodo Monte Carlo.*

È un metodo introdotto per calcolare la media di v.a. quando non si possono usare le tecniche dirette.

Se  $X$  è una v.a. e se  $f$  è una funzione di  $X$ , supponiamo di poter simulare  $n$  valori di  $X$ , diciamo  $x_1, \dots, x_n$ . Allora,

$$E[f(X)] \approx \frac{1}{n} \sum_{i=1}^n f(x_i) .$$

Poichè si tratta di approssimazioni, dobbiamo essere sicuri che il valore ottenuto sia “buono”: la Legge dei Grandi Numeri ci assicura che il valore approssimato converge al valore vero, mentre il Teorema del limite centrale ci dice che

$$\frac{1}{n} \sum_{i=1}^n f(x_i) \sim \mathcal{N} \left( E(f(X)), \frac{1}{n} Var(f(X)) \right) .$$

Quindi, l'approssimazione ottenuta si discosta dal valore vero di una quantità dell'ordine di  $\frac{1}{\sqrt{n}}$ , allora, maggiore sarà  $n$ , migliore sarà la nostra approssimazione.

Il metodo Monte Carlo è particolarmente adatto per approssimare il valore di integrali definiti:

$$\int_a^b f(x)dx, \text{ essendo } f : [a, b] \rightarrow [c, d].$$

Procediamo come segue:

- sia  $A := (b - a) \cdot (d - c)$  e sia  $j := 0$  (contatore)
- estraiamo un numero casuale uniforme  $u \in [a, b]$  ed un altro numero casuale uniforme  $v \in [c, d]$
- se  $v < f(u)$ , allora incrementiamo il contatore:  $j = j + 1$
- iteriamo la procedura  $n$  volte

Allora, si ha

$$\int_a^b f(x)dx \approx \frac{As}{n}.$$

In pratica, il metodo Monte Carlo conta quanti punti, di coordinate aleatorie  $(u, v)$ , cadono sopra o sotto la curva di equazione  $f$ . Il numero di punti al di sotto della curva è  $s/n$ . Dunque, l'integrale che vogliamo calcolare (area della parte di piano) è  $A \cdot \frac{s}{n}$ .

In particolare, se scegliamo  $f(x) = 1 - x^2$ ,  $x \in [-1, 1]$ , ci riduciamo a calcolare l'area del semicerchio di raggio 1, inscritto in un quadrato di lato 1. Con la tecnica appena descritta, otteniamo che l'area cercata è  $\pi$ .

**Esercizio 2.1.** *Una compagnia di assicurazione ha 25000 polizze attive. Ciascun assicurato percepisce un risarcimento annuo che rappresenta una v.a. che si distribuisce con media pari a 320 € e scarto quadratico medio pari a 540 €. Qual è la probabilità che la compagnia paghi complessivamente 8300000 €?*

**Esercizio 2.2.** *Il numero ideale di studenti di un corso del primo anno di università è 150. Il management didattico dell'università sa che, in base agli anni precedenti, solo il 30% degli iscritti frequenta effettivamente i corsi, dunque decide di accettare fino a 450 nuove iscrizioni. Qual è la probabilità che il numero di studenti frequentanti sia superiore a 150?*